

ИНТЕЛЛЕКТУАЛЬНЫЕ ТРАНСПОРТНЫЕ СИСТЕМЫ/INTELLIGENT TRANSPORT SYSTEMS

DOI: <https://doi.org/10.60797/IRJ.2025.162.42>

МАШИННОЕ ОБУЧЕНИЕ В УПРАВЛЕНИИ РИСКАМИ ГЛОБАЛЬНЫХ ЦЕПОЧЕК ПОСТАВОК: МЕТОДЫ, ИНТЕРПРЕТАЦИЯ И ВЫЗОВЫ ВНЕДРЕНИЯ

Научная статья

Матвеев Р.В.¹, Матвеев В.Н.^{2,*}¹ORCID : 0009-0003-2780-2943;²ORCID : 0000-0002-6142-5710;¹ Институт экономики, математики и информационных технологий при Президентской академии, Москва, Российская Федерация² Московский государственный университет имени М. В. Ломоносова, Москва, Российская Федерация

* Корреспондирующий автор (13121946vnm[at]gmail.com)

Аннотация

В статье рассматривается использование методов машинного обучения для прогнозирования и предотвращения сбоев в глобальных цепочках поставок. Основной упор в статье сделан на минимизации рисков, лучших практиках и принципах для предотвращения сбоев в цепочках поставок. Упомянута важность гибридных подходов, в которых алгоритмы сочетаются с экспертными оценками, роли качества и прозрачности данных. Обозначены ключевые проблемы: нехватка размеченных данных, сложность интерпретации моделей, риски утечек чувствительных данных и высокая вычислительная нагрузка.

Глобальные цепочки поставок сегодня сталкиваются с частыми сбоями из-за пандемий, геополитики, нехватки ресурсов и изменений спроса. Это создает сложные риски, которые традиционные методы оценки и управления уже не могут решать эффективно. Машинное обучение позволяет выявлять скрытые паттерны и прогнозировать риски в реальном времени, что становится критично важным для устойчивости и сохранения конкурентоспособности компаний.

Цель работы — рассмотреть современные методы машинного обучения для управления рисками в глобальных цепочках поставок, выявить их ограничения и проблемы внедрения. Для этого были поставлены задачи: провести обзор литературы и существующих решений, классифицировать подходы по используемым методам и областям, проанализировать проблемы интерпретации и качества данных, оценить перспективы развития технологий.

Ключевые слова: машинное обучение, цепочки поставок, управление рисками, предиктивная аналитика.

MACHINE LEARNING IN GLOBAL SUPPLY CHAIN RISK MANAGEMENT: METHODS, INTERPRETATION AND IMPLEMENTATION CHALLENGES

Research article

Matveenko R.V.¹, Matveenko V.N.^{2,*}¹ORCID : 0009-0003-2780-2943;²ORCID : 0000-0002-6142-5710;¹ Institute of Economics, Mathematics and Information Technologies at the Presidential Academy, Moscow, Russian Federation² Lomonosov Moscow State University, Moscow, Russian Federation

* Corresponding author (13121946vnm[at]gmail.com)

Abstract

The article examines the use of machine learning methods to predict and prevent disruptions in global supply chains. The main focus of the paper is on risk minimisation, best practices and principles for preventing supply chain disruptions. The importance of hybrid approaches, in which algorithms are combined with expert assessments, and the role of data quality and transparency are mentioned. Key challenges are identified: lack of labelled data, complexity of model interpretation, risks of sensitive data leaks, and high computational load.

Global supply chains today face frequent disruptions due to pandemics, geopolitics, resource shortages and changes in demand. This creates complex risks that traditional evaluation and management methods can no longer address effectively. Machine learning enables the identification of hidden patterns and real-time risk prediction, which is becoming critical to the sustainability and competitiveness of companies.

The aim of the work is to examine modern machine learning methods for risk management in global supply chains, identify their limitations and implementation issues. To this end, the following tasks were set: to review the literature and existing solutions, to classify approaches according to the methods and areas used, to analyse problems of interpretation and data quality, and to evaluate the prospects for technological development.

Keywords: machine learning, supply chains, risk management, predictive analytics.

Введение

В ведущих исследованиях прослеживается закономерность: традиционные статистические методы и простые системы бизнес-аналитики больше не справляются с современными рисками глобальных цепочек поставок — слишком много сложных и разнотипных данных, слишком быстро и часто меняются системы.

Методы машинного обучения находят применение в задачах раннего выявления сбоев, оптимизации маршрутов, прогнозирования спроса, оценки рисков по большому числу разнородных факторов. В работах Нерони и её коллег подчёркивается: на практике лучшие результаты дают гибридные подходы — сочетание ML с экспертными оценками, когда алгоритмы выявляют скрытые паттерны, а специалисты добавляют контекст и учитывают отраслевые аспекты. Янг с соавторами систематизируют используемые алгоритмы: глубокое обучение и ансамбли моделей лучше подходят для работы с неструктурированными и сложными данными, но требуют понимания того, как формируется прогноз, поэтому сейчас быстро растёт интерес к объяснительному искусственному интеллекту и техникам интерпретации моделей.

Большая часть работ делает упор на важности высокого качества данных — ошибки и шум на входе приводят к искажённым результатам, поэтому во многих проектах внедряются системы сквозной проверки и очистки информации. По отдельным аспектам активно изучаются способы интеграции ML в корпоративные платформы (WMS, ERP, TMS), вопросы безопасности, конфиденциальности и адаптации моделей к быстро меняющимся внешним условиям. Как показывают мета-анализы и прикладные примеры, правильно внедрённые решения с искусственным интеллектом способны увеличить скорость и точность обнаружения рисков на 10–20% по сравнению с чисто экспертными системами. Несмотря на внедрение новых методов по-прежнему сохраняется проблема нехватки размеченных данных, проблемы интерпретируемости, «узкие места» при интеграции, разрыв между ИТ и бизнес-целями компаний. Это и стало предметом исследования нашей работы.

В эпоху экспоненциально развивающихся технологических решений, компании, для сохранения конкурентного преимущества вынуждены следовать современным трендам цифровизации один из которых — это предиктивная аналитика и анализ больших данных, особенно актуальным является промышленное применение подобных технологий в логистических цепях поставок для снижения издержек и увеличения экономического эффекта [1], [2], [3]. Переход к многополярному миру и деглобализации совместно с повсеместным развитием протекционистских мер, увеличивает риски связанные с кибератаками, политической нестабильностью, а также с нестабильным спросом на продукцию в условиях протекционистских мер, особенно в развитых странах [4, С. 103]. Большую роль играет фактор неопределённости, который подталкивает к поиску новых решений в технологическом процессе управления рисками в цепочке поставок. Этот процесс направлен на снижение уязвимости и поддержание непрерывности в логистических цепочках. Постоянство в логистических цепочках обеспечивает бесперебойность в производственных процессах, лучшую конкурентную цену для конечных потребителей за счет оптимальных логистических маршрутов и лучшего времени доставки грузов, что способствует дополнительному экономическому росту. Современные риски в цепочке поставок слишком велики, чтобы любая компания могла справиться с ними самостоятельно. Чтобы справляться с этими глобальными вызовами, фирмы должны следовать международным стандартам. Проверенные системы, такие как ISO 28000 и NIST Cybersecurity Framework, предлагают практические рекомендации [5], [6]. Они предлагают четкие шаги по созданию более надежных систем, способных справляться с перебоями в работе.

Для анализа применялись сравнительный метод и изучение литературы, включая практические примеры использования машинного обучения в управлении рисками. Рассматривались количественные данные и качественные описания. В основу положены принципы системности, комплексности и сопоставимости: риски анализировались как часть всей цепочки, учитывались технические и организационные факторы, а также проводилось сравнение традиционных и новых подходов. Такой подход позволил выявить сильные и слабые стороны технологий и определить условия их наиболее эффективного применения.

Основные результаты

Проведённый анализ показывает, что применение машинного обучения в управлении рисками цепочек поставок ускоряет выявление угроз и повышает точность обнаружения сбоев на 10–20% по сравнению с классическими статистическими моделями. Наибольшая практическая отдача достигается в задачах прогнозирования задержек, поиске аномалий в поставках и разборе факторов, влияющих на устойчивость цепочек. Гибридный подход — алгоритмов машинного обучения в сочетании с экспертными оценками — дают более надёжные результаты и помогает держать баланс между скоростью анализа и обоснованностью выводов. Интеграция с корпоративными системами WMS, ERP и TMS и автоматизация потоков формируют более адаптивную платформу управления логистикой. Вместе с тем остаются ограничения: зависимость от качества данных, необходимость разметки, подготовка инфраструктуры и риски ложных срабатываний на старте внедрения. Проблема интерпретируемости снижает доверие к моделям и требовательна к процедурам валидации. Методики SHAP и LIME повышают прозрачность решений, но требуют аккуратной настройки и корректной эксплуатации в продуктивных контурах. Вопросы защиты данных и соблюдения регламентов остаются ключевыми вызовами при работе с большими массивами информации в SCRM системах.

Обсуждение

Можно выделить несколько методов и моделей используемых в глобальных цепях поставок для предсказания, смягчения и предотвращения рисков — предиктивная аналитика и машинное обучение, системы мониторинга в режиме реального времени, обработка естественного языка, анализ временных рядов, обнаружение аномалий.

Машинное обучение используемое при управлении рисками в цепочках поставок позволяет выявлять возможные причины нарушений при анализе исторических данных в прошлом для реактивного и проактивного реагирования на схожие закономерности в будущем с помощью анализа данных поступающих в режиме реального времени [7], [8]. Существует большое множество исследований описывающих преимущества и недостатки внедрения технических систем основанных на методах кластеризации, регрессионного анализа, нейронных сетей. В специализированных статьях по управлению рисками в цепочках поставок (Supply Chain Risk Management, далее — SCRM), часто упоминается о необходимости одновременного использования систем мониторинга в реальном времени с системами предиктивной аналитики [8]. К примеру в работе Абира Аль-Джохани исследовалась необходимость объединения

классического подхода и предиктивной аналитики для своевременного превентивного принятия решений для минимизации последствий серьезных отклонений, один из методов — метод кластеризации (например, метод k-средних) эффективно группирует поставщиков по профилям рисков, подобные алгоритмы позволяют выявлять скрытые группы риска или аномалии без предопределенных меток, чего не хватает традиционным методам при ручной оценке рисков в режиме реального времени для проактивного снижения рисков [9].

Методологической основой исследования стали концепции предиктивной аналитики и управления рисками в цепочках поставок, методы количественного анализа данных и машинного обучения, а также современные тренды в области искусственного интеллекта, применяемые для прогнозирования и предотвращения сбоев поставщиков. Основные принципы и концепции используемые для прогнозирования и предотвращения сбоев поставщиков в глобальных цепочках поставок в особенности в управление рисками в цепочках поставок включают в себя:

1. Распространенные алгоритмы машинного обучения (Machine Learning, MO, ML) в управлении рисками цепочек поставок (Supply Chain Risk Management, SCRM).

Выделяют метод опорных векторов (Support Vector Machine, SVM), логистическую регрессию (Logistic Regression, LR), глубокое обучение (Deep Learning, DL), дерево решений (Decision Tree, DT), байесовские сети (Bayesian Network, BN), нейронные сети (Neural Network, NN), случайный лес (Random Forest, RF), ансамблевое обучение (Ensemble Learning, EL), экстремальное обучение (Extreme Learning Machine, ELM), кластеризация и наивный байесовский метод. Данные алгоритмы помогают снижать риски цепочки поставок и повышать производительность [10].

2. Приоритизацию каузального машинного обучения (CML) для прогнозирования рисков и интерпретируемости.

Каузальное машинное обучение превосходит классические подходы машинного обучения при прогнозировании рисков, интерпретируемости и поддержке принятия решений переходя от «чёрного ящика» к белому, что позволяет выявлять причинно-следственные связи воздействующие на поставщиков [11], [12]. В экспертной среде показатели согласия о возможности перехода от нынешних к прогнозным и каузальным моделям составляет (75,2%) [11]. Причинное машинное обучение демонстрирует превосходство над классическим машинным обучением в точности, способности к обучению, снижению риска человеческого фактора, а также при критических стресс ситуациях, и при восстановлении после них.

3. Повышение интерпретируемости МО (Explainable AI - XAI).

Проблемы в интерпретации и отсутствие уверенности в результатах особенно при применении в корпоративном секторе требуют большего времени тестирования при внедрении модулей в больших системах ввиду вероятности серьезных экономических рисков и потенциальных сбоев после применений решений основанных на вспомогательных системах [13].

4. Фокусировку на конкретных рисках и их раннем выявлении.

Применение машинного обучения в логистических цепочках в первую очередь направлено на поиск и выявление аномалий связанных с транспортными, производственными, и продовольственными рисками для оперативного реагирования, также стоит отметить, что риски связанные с продажами и качественными изменениями в исследованиях встречаются в меньшей степени [3].

5. Важность проактивного подхода и прозрачность данных.

С увеличением объема данных увеличивается потребность в их обработке, благодаря IoT (Internet Of Things) приборам, и датчикам, появилась возможность получать, обрабатывать и анализировать каждый этап бизнес-процесса. Для очистки данных многие компании использующие data-driven подход выстраивают системы качества данных (Data Quality, DQ) для поддержания чистоты и актуальности данных в хранилищах данных (Data Warehouse, DWH) [14], [15].

Проактивный подход должен использоваться не только при алгоритмах проектирования моделей, но и при проектировании архитектурного стека, который в свою очередь может быть подвержен следующим цифровым рискам цепочки поставок (Digital Supply Chain Risks): риски зависимости от открытого исходного кода, риски сторонних поставщиков программного обеспечения, операционные ИТ-риски. При этом ключевая сложность заключается в том, что современные ИТ-системы редко разрабатываются полностью автономно — они активно используют открытое программное обеспечение, сторонние библиотеки и сервисы [5]. Это создаёт скрытые уязвимости: например, прекращение поддержки open-source проекта, изменение лицензии, появление уязвимостей в зависимостях или нарушения совместимости. Такие ситуации способны парализовать работу критически важных систем, таких как WMS (Warehouse Management System), ERP (Enterprise Resource Planning) или TMS (Transportation Management System), что напрямую повлияет на физические процессы в цепочке поставок [16], [17].

6. Необходимость размеченных данных для обучения, работа с высоким уровнем ложных срабатываний на начальном этапе внедрения и необходимость экспертной валидации результатов.

7. Важность экспертных заключений и гибридных методов.

Чистый ML иногда упускает нюансы, которые люди видят сразу. Экспертные мнения помогают заполнить пробелы в данных и сделать предсказания более надежными. Например, менеджеры по поставкам могут учесть локальные факторы, как культурные особенности или неформальные отношения, которые алгоритмы игнорируют. Гибридные методы сочетают это с ML-алгоритмы обрабатывают большие объемы данных, а эксперты интерпретируют результаты. Исследования показывают, что такие подходы повышают точность на 10–20% в прогнозировании сбоев, особенно в сложных сценариях вроде пандемий [18], [19]. Они снижают риски «черного ящика», делая модели понятнее для решений. В практике гибриды включают экспертные системы, где ML предлагает варианты, а люди корректируют на основе опыта.

Вызовы и ограничения внедрения указанных методов отчетливо виднеющиеся при анализе включают в себя: необходимость размеченных данных для обучения, конфиденциальность и безопасность данных, вычислительная сложность и стоимость развертывания ML-инфраструктуры, проблемы интерпретируемости моделей. Сложность

сбора полных и размеченных данных обусловлен халатностью производственного персонала, а также стоимостью полной разметки данных в реальном производственном процессе [20].

В тестовых исследованиях часто наблюдается несбалансированность данных при обнаружении аномалий между соотношением положительных и отрицательных выборок тестовых данных, что затрудняет эффективную оценку модели стандартными метриками точности [20]. Машинное обучение уже имеет хорошую доказательную базу при использовании алгоритмов в области менеджмента рисками цепочек поставок, сдерживающими факторами для развития и внедрения подобных технологий являются сложность в интерпретации результатов и качество данных. Гибридные подходы с применением независимых экспертных оценок и результатов работы алгоритмов должны быть приоритетными в момент принятия решений основанных на системах поддержки принятия решений. Необходимость каузальных систем продиктована сложностью интерпретации систем с непрозрачными алгоритмами. Для улучшения интерпретации стоит внедрять метод SHAP (Shapley Additive exPlanations), который позволяет понимать какой вклад в конечный результат оценки внес тот или иной признак, а также метод LIME (Local Interpretable Model-agnostic Explanations), который создает упрощенную модель для объяснения предсказания отдельного экземпляра [21], [22]. Высокая стоимость внедрения ML моделей и разрыв в компетенциях ML-специалистов и менеджеров по поставкам затрудняет повсеместное быстрое внедрение подобных систем.

Заключение

Новизна и оригинальность работы заключается в проведении системного обзора методов ML для цепочек поставок на основе последних исследований. Описаны реальные организационные проблемы внедрения — интерпретируемость, нехватка обучающих данных, риски потери информации. Особое внимание уделено интеграции с современными стандартами (ISO 28000, NIST) и возможности и рискам использования открытых API и платформ для наращивания устойчивости к внешним шокам.

Машинное обучение уже занимает заметное место в управлении рисками цепочек поставок. Оно помогает находить скрытые уязвимости и реагировать на сбои быстрее, чем традиционные методы. Но полагаться только на алгоритмы машинного обучения пока нельзя: для их работы нужны большие объёмы качественных и размеченных данных, сами модели часто остаются «чёрным ящиком», а внедрение требует серьёзных затрат и компетенций. Более надёжные результаты даёт сочетание алгоритмов с экспертными оценками. Правильно настроенные системы умеют обрабатывать данные в масштабе и замечать слабые сигналы, которые человек пропустил бы, а эксперты учитывают контекст, опыт и факторы, которые сложно оцифровать. Такой гибридный подход снижает человеческий фактор и делает решения устойчивее. Важным направлением развития остаётся прозрачность. Методы объяснимого ИИ вроде SHAP и LIME позволяют понять, какие признаки влияют на прогноз, а причинное машинное обучение помогает видеть не только корреляции, но и связи между событиями. Это повышает доверие к моделям и облегчает принятие решений. В ближайшие годы роль машинного обучения в цепочках поставок будет только расти: от предсказания сбоев и аномалий оно постепенно будет больше использоваться и для прогнозирования спроса, качества и продаж [23]. Компании, которые научатся работать с данными и встраивать такие методы в процессы, будут лучше справляться с нестабильностью и быстрее адаптироваться к изменениям.

Конфликт интересов

Не указан.

Рецензия

Гибадуллин Р.Ф., Казанский национальный исследовательский технический университет им. А.Н. Туполева – КАИ, Казань Российская Федерация
DOI: <https://doi.org/10.60797/IRJ.2025.162.42.1>

Conflict of Interest

None declared.

Review

Gibadullin R.F., Kazan National Research Technical University named after A.N. Tupolev – KAI, Kazan Russian Federation
DOI: <https://doi.org/10.60797/IRJ.2025.162.42.1>

Список литературы / References

1. Гибадуллин Р.Ф. Анализ параметров промышленных сетей с применением нейросетевой обработки / Р.Ф. Гибадуллин, Д.В. Лекомцев, М.Ю. Перухин // Искусственный интеллект и принятие решений. — 2020. — Т. 1. — С. 80–87. DOI: [10.14357/20718594200108](https://doi.org/10.14357/20718594200108)
2. Gupta I. A Comparative Assessment of Causal Machine Learning and Traditional Methods for Enhancing Supply Chain Resiliency and Efficiency in the Automotive Industry / I. Gupta, A. Martinez, S. Correa [et al.] // Supply Chain Analytics. — 2025. — Vol. 10. — P. 100116.
3. International Organization for Standardization. ISO 22301:2022. Security and resilience — Security management systems : requirements. — 2nd ed. — International Organization for Standardization, 2022. — 12 p.
4. Киселев И.С. Применение аналитики для минимизации рисков и оптимизации процессов в логистике и цепочках поставок / И.С. Киселев // Russian Economic Bulletin. — 2025. — Т. 8, № 1. — С. 153–160.
5. Liao Q.V. Questioning the AI: Informing Design Practices for Explainable AI User Experiences / Q.V. Liao, D. Gruen, S. Miller // Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems. — 2020. — P. 1–15. — URL: <http://arxiv.org/abs/2001.02478> (accessed: 05.09.2025).
6. Makridakis S. The M4 Competition: Conclusions / S. Makridakis, F. Petropoulos // International Journal of Forecasting. — 2020. — Vol. 36, № 1. — P. 224–227.
7. Neroni M. A Supply Chain Analytics Approach for Optimizing Milk Collection Routing in Multi-Depot Networks / M. Neroni, M. Rinaldi // Supply Chain Analytics. — 2025. — Vol. 10. — P. 100123.

8. Yang M. Supply Chain Risk Management with Machine Learning Technology: A Literature Review and Future Research Directions / M. Yang, M.K. Lim, Y. Qu [et al.] // *Computers & Industrial Engineering*. — 2023. — Vol. 175. — P. 108859.
9. Roushan A. A Multi-Objective Supply Chain Model for Disaster Relief Optimization Using Neutrosophic Programming and Blockchain-Based Smart Contracts / A. Roushan, A. Das, A. Dutta [et al.] // *Supply Chain Analytics*. — 2025. — Vol. 10. — P. 100107.
10. Haque S. A Scoping Review of Export Supply Chain Efficiency Frameworks for Perishable Horticultural Products / S. Haque, D. Akbar, S. Kinnear [et al.] // *Supply Chain Analytics*. — 2025. — Vol. 10. — P. 100112.
11. Aljohani A. Predictive Analytics and Machine Learning for Real-Time Supply Chain Risk Mitigation and Agility / A. Aljohani // *Sustainability*. — 2023. — Vol. 15, № 20. — P. 15088.
12. Bambi Q. Supply Chain Risk Management Using Predictive Analytics / Q. Bambi, W. Elijah. — URL: https://www.researchgate.net/publication/389357100_Supply_Chain_Risk_Management_Using_Predictive_Analytics (accessed: 05.09.2025).
13. Boyens J.M. Cybersecurity Supply Chain Risk Management Practices for Systems and Organizations / J.M. Boyens. — Gaithersburg, MD : National Institute of Standards and Technology, 2024.
14. Broniatowski D.A. Psychological Foundations of Explainability and Interpretability in Artificial Intelligence / D.A. Broniatowski. — Gaithersburg, MD : National Institute of Standards and Technology (U.S.), 2021.
15. Chen Y.-M. A Machine Learning-Based Anomaly Detection Method and Blockchain-Based Secure Protection Technology in Collaborative Food Supply Chain / Y.-M. Chen, T.-Y. Chen, J.-S. Li // *International Journal of e-Collaboration*. — 2023. — Vol. 19, № 1. — P. 1–24.
16. Herzog C. Machine Learning Has Revolutionized Forecasting During COVID-19. — URL: <https://www.oliverwyman.com/our-expertise/insights/2020/nov/machine-learning-will-revolutionize-forecasting.html> (accessed: 05.09.2025).
17. Schroeder M. A Systematic Investigation of the Integration of Machine Learning into Supply Chain Risk Management / M. Schroeder, S. Lodemann // *Logistics*. — 2021. — Vol. 5, № 3. — P. 62.
18. Taleb I. Big Data Quality: A Data Quality Profiling Model / I. Taleb, M.A. Serhani, R. Dssouli // *Services – SERVICES 2019: Lecture Notes in Computer Science*. — Cham : Springer International Publishing, 2019. — Vol. 11517. — P. 61–77.
19. Machine Learning and Artificial Intelligence Methods and Applications for Post-Crisis Supply Chain Resiliency and Recovery // *Supply Chain Analytics*. — 2025. — Vol. 10. — P. 100121.
20. Акимова А.О. Протекционизм в условиях формирования многополярного мира суверенных государств / А.О. Акимова, Р.Х. Айнетдинов // *Post-Soviet Continent*. — 2025. — № 1. — С. 99–107.
21. Что внутри черного ящика: понимаем работу ML-модели с помощью SHAP // *Habr*. — URL: <https://habr.com/ru/companies/wunderfund/articles/739744/> (дата обращения: 15.09.2025).
22. LIME for ECG Time Series Dataset Example // *Habr*. — URL: <https://habr.com/ru/articles/926082/> (accessed: 15.09.2025).
23. Импортзамещение Data Quality стека в нефтегазохимии: опыт СИБУРа // *Habr*. — URL: https://habr.com/ru/companies/sibur_official/articles/855310/ (дата обращения: 01.09.2025).

Список литературы на английском языке / References in English

1. Gibadullin R.F. Analiz parametrov promyshlennykh setei s primeneniem neirosetevoi obrabotki [Analysis of industrial network parameters using neural network processing] / R.F. Gibadullin, D.V. Lekomtsev, M.Yu. Perukhin // *Iskusstvennyi intellekt i prinyatie reshenii* [Artificial Intelligence and Decision Making]. — 2020. — Vol. 1. — P. 80–87. DOI: 10.14357/20718594200108 [in Russian]
2. Gupta I. A Comparative Assessment of Causal Machine Learning and Traditional Methods for Enhancing Supply Chain Resiliency and Efficiency in the Automotive Industry / I. Gupta, A. Martinez, S. Correa [et al.] // *Supply Chain Analytics*. — 2025. — Vol. 10. — P. 100116.
3. International Organization for Standardization. ISO 22301:2022. Security and resilience — Security management systems : requirements. — 2nd ed. — International Organization for Standardization, 2022. — 12 p.
4. Kiselev I.S. Primenenie analitiki dlya minimizatsii riskov i optimizatsii protsessov v logistike i tsepochkakh postavok [Application of analytics for risk minimization and process optimization in logistics and supply chains] / I.S. Kiselev // *Russian Economic Bulletin*. — 2025. — Vol. 8, № 1. — P. 153–160. [in Russian]
5. Liao Q.V. Questioning the AI: Informing Design Practices for Explainable AI User Experiences / Q.V. Liao, D. Gruen, S. Miller // *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*. — 2020. — P. 1–15. — URL: <http://arxiv.org/abs/2001.02478> (accessed: 05.09.2025).
6. Makridakis S. The M4 Competition: Conclusions / S. Makridakis, F. Petropoulos // *International Journal of Forecasting*. — 2020. — Vol. 36, № 1. — P. 224–227.
7. Neroni M. A Supply Chain Analytics Approach for Optimizing Milk Collection Routing in Multi-Depot Networks / M. Neroni, M. Rinaldi // *Supply Chain Analytics*. — 2025. — Vol. 10. — P. 100123.
8. Yang M. Supply Chain Risk Management with Machine Learning Technology: A Literature Review and Future Research Directions / M. Yang, M.K. Lim, Y. Qu [et al.] // *Computers & Industrial Engineering*. — 2023. — Vol. 175. — P. 108859.
9. Roushan A. A Multi-Objective Supply Chain Model for Disaster Relief Optimization Using Neutrosophic Programming and Blockchain-Based Smart Contracts / A. Roushan, A. Das, A. Dutta [et al.] // *Supply Chain Analytics*. — 2025. — Vol. 10. — P. 100107.

10. Haque S. A Scoping Review of Export Supply Chain Efficiency Frameworks for Perishable Horticultural Products / S. Haque, D. Akbar, S. Kinnear [et al.] // *Supply Chain Analytics*. — 2025. — Vol. 10. — P. 100112.
11. Aljohani A. Predictive Analytics and Machine Learning for Real-Time Supply Chain Risk Mitigation and Agility / A. Aljohani // *Sustainability*. — 2023. — Vol. 15, № 20. — P. 15088.
12. Bambi Q. Supply Chain Risk Management Using Predictive Analytics / Q. Bambi, W. Elijah. — URL: https://www.researchgate.net/publication/389357100_Supply_Chain_Risk_Management_Using_Predictive_Analytics (accessed: 05.09.2025).
13. Boyens J.M. Cybersecurity Supply Chain Risk Management Practices for Systems and Organizations / J.M. Boyens. — Gaithersburg, MD : National Institute of Standards and Technology, 2024.
14. Broniatowski D.A. Psychological Foundations of Explainability and Interpretability in Artificial Intelligence / D.A. Broniatowski. — Gaithersburg, MD : National Institute of Standards and Technology (U.S.), 2021.
15. Chen Y.-M. A Machine Learning-Based Anomaly Detection Method and Blockchain-Based Secure Protection Technology in Collaborative Food Supply Chain / Y.-M. Chen, T.-Y. Chen, J.-S. Li // *International Journal of e-Collaboration*. — 2023. — Vol. 19, № 1. — P. 1–24.
16. Herzog C. Machine Learning Has Revolutionized Forecasting During COVID-19. — URL: <https://www.oliverwyman.com/our-expertise/insights/2020/nov/machine-learning-will-revolutionize-forecasting.html> (accessed: 05.09.2025).
17. Schroeder M. A Systematic Investigation of the Integration of Machine Learning into Supply Chain Risk Management / M. Schroeder, S. Lodemann // *Logistics*. — 2021. — Vol. 5, № 3. — P. 62.
18. Taleb I. Big Data Quality: A Data Quality Profiling Model / I. Taleb, M.A. Serhani, R. Dssouli // *Services – SERVICES 2019: Lecture Notes in Computer Science*. — Cham : Springer International Publishing, 2019. — Vol. 11517. — P. 61–77.
19. Machine Learning and Artificial Intelligence Methods and Applications for Post-Crisis Supply Chain Resiliency and Recovery // *Supply Chain Analytics*. — 2025. — Vol. 10. — P. 100121.
20. Akimova A.O. Proteksionizm v usloviyakh formirovaniya mnogopolyarnogo mira suverennykh gosudarstv [Protectionism in the context of the formation of a multipolar world of sovereign states] / A.O. Akimova, R.Kh. Ainetdinov // *Post-Soviet Continent*. — 2025. — № 1. — P. 99–107. [in Russian]
21. Chto vnutri chernogo yashchika: ponimaem rabotu ML-modeli s pomoshch'yu SHAP [What's inside the black box: understanding the operation of an ML model using SHAP] // *Habr*. — URL: <https://habr.com/ru/companies/wunderfund/articles/739744/> (accessed: 15.09.2025). [in Russian]
22. LIME for ECG Time Series Dataset Example // *Habr*. — URL: <https://habr.com/ru/articles/926082/> (accessed: 15.09.2025).
23. Importozameshchenie Data Quality steka v neftegazokhimii: opyt SIBURa [Import substitution of the Data Quality stack in petrochemicals: SIBUR's experience] // *Habr*. — URL: https://habr.com/ru/companies/sibur_official/articles/855310/ (accessed: 01.09.2025). [in Russian]